

CNN을 이용한 차량용 카메라 이미지센서의 고장진단

이준혁, 권민경, 김영범, 허장욱*
금오공과대학교 기계시스템공학과

Failure Diagnostics of Camera Image Sensor For Vehicle Using CNN

Joon-Hyuk Lee, Min-Gyeong Kwon, Young-Beom Kim, Jang-Wook Hur*
Department of Mechanical System Engineering, Kumoh National Institute of Technology

요약 최근 자율주행 기술 개발과 함께 차량 내 카메라 모듈 수가 확대되며 활용 기술이 다양해지고 있다. 차량용 카메라는 여러 가지 노출 환경으로 인해 다양한 종류의 고장이 발생하여 높은 신뢰성이 요구되며, 그중 주변 환경을 영상으로 출력하는 이미지센서의 역할이 중요하다. 전자장비에 PHM을 적용하는 경우 상태를 관찰할 수 있는 센서를 부착하는 과정이 어려워 전기적인 신호 출력 값들을 추출하기가 쉽지 않다. 따라서, 본 연구에서는 차량용 카메라에 대해 FMEA를 적용하여 기능별 잠재적 결함을 분석하고, 센서 부착으로 인해 회로기판에 영향을 주지 않기 위해 이미지를 통해 이미지센서의 상태를 진단하는 딥러닝 모델을 제작하였다. 동영상을 프레임마다 분류해야 하므로 단위 시간당 많은 연산을 처리할 수 있는 CNN의 주요 모델 중 VGGNet을 기반으로 학습을 진행하였고, 전체 데이터를 50%, 25%, 25%로 나누어 각각 Training, Validating, Testing 데이터로 사용하였다. 이미지 손상 정도에 따라 고장진단분류 학습결과 Precision, Recall, F1-Score 및 Accuracy는 평균 92.6%의 성능을 확인하였으며, Grad-CAM을 사용하여 모델이 정확하게 학습되었는지 검증하였다. 본 실험에서 사용된 시편의 수가 적어 가속수명시험 적용이 제한되었으며, 충분한 시편의 수와 가속성 검증을 고려한 가속수명시험을 통해 데이터를 수집하면 정확한 수명예측도 가능할 것으로 기대된다.

Abstract With the recent development of autonomous driving technology, the number of camera modules in the vehicle is expanding, and the technology to utilize is diversifying. Vehicle cameras require high reliability because of various failures caused by various exposure environments. Among them, the role of an image sensor that outputs the surrounding environment as an image is important. When PHM is applied to electronic devices, extracting the electrical signal output value is problematic because it is difficult to attach a sensor that can observe the state. Therefore, this study applied FMEA to a vehicle camera to analyze potential defects by function. A deep learning model was developed to diagnose the state of the image sensor through images so that the sensor attachment does not affect the circuit board. Because videos have to be classified for each frame, training was conducted based on VGGNet among the main models of CNN that can process many operations per unit of time. The total data was divided into 50%, 25%, and 25% and used as training, validating, and testing data, respectively. As a result of learning the fault diagnosis classification according to the degree of image damage, the performance of precision, recall, F1-Score, and accuracy was 92.6% on average, and the model was verified using Grad-CAM. As the number of samples used in this experiment was small, there was a limit to the application of the accelerated life test. Accurate life prediction may be possible if data are collected through the accelerated life test considering the sufficient number of samples and acceleration verification.

Keywords : Machine Learning, Image Sensor, Failure Diagnostics, Failure Mode and Effect Analysis, Prognostics and Health Management

본 논문은 과학기술정보통신부 및 정보통신기획평가원의 지역지능화혁신인재양성(Grand ICT연구센터) 사업의 연구결과(IITP-2022-2020-0-01612)로 수행되었음.

*Corresponding Author : Jang-Wook Hur(Kumoh National Institute of Technology)
email: hhjw88@kumoh.ac.kr

Received October 31, 2022
Accepted December 7, 2022

Revised November 29, 2022
Published December 31, 2022

1. 서론

4차 산업 혁명에 있어 머신러닝이 차지하는 비중은 날이 증가하고 있다. 성공적인 머신러닝을 위해서는 방대한 데이터양을 나타내는 빅데이터가 필수적인데, 이러한 빅데이터는 공학적 분야뿐만 아니라 여러 분야에 활용이 되고 있어 연구개발이 꾸준히 진행되고 있다. 이와 함께 장비의 상태를 실시간 감시 및 감지하고, 고장을 예측하는 기술인 진전성 예측 및 관리 기술(PHM, Prognostics and Health Management) 역시 머신러닝을 기반으로 한 연구들이 활발하게 진행되고 있다[1]. 그리고 궁극적으로 이러한 데이터로부터 대상의 공학적 수명 및 경제적 가치를 분석하는 것이 가장 중요하다.

최근 자율주행 기술 개발과 함께 차량 내 카메라 모듈 수가 확대되며 그 활용 기술이 다양해지고 있다. 특히, 차량용 카메라는 안전한 주행을 위한 필수 부품으로써 그 중요성이 높아지고 있는 것은 물론이며, 환경변화를 감지하고 사고까지 미리 방지 가능한 기능을 구현 및 적용하고 있다[2]. 자동차에 들어가는 카메라는 여러 가지 노출 환경으로 인해 다양한 종류의 고장이 발생하고 있기 때문에 높은 신뢰성을 요구하고 있으며, 그중 카메라 모듈에서 주변 환경을 영상으로 출력하는 이미지센서의 역할이 특히 중요하다.

전자장비에 PHM을 적용하는 경우 일반적으로 회로 보드에 센서를 부착하여 전기적 신호의 출력값들을 이용하여 불량을 판단하게 된다. 하지만 센서 부착과정에서 회로보드의 단선과 납땜 작업이 요구되며 이 과정에서 회로보드가 손상되는 경우가 빈번하다. 전류 및 전압 데이터 수집을 위한 센서를 부착할 경우 내부 회로가 단락되거나 합선이 발생할 수 있고 기판이 손상될 수도 있다. 특히 차량용 카메라와 같은 소프트웨어융합형 부품의 경우 각각의 부품에 센서를 부착해야 하므로 회로보드가 손상될 위험이 증가하게 된다.

또한, 전기적인 신호 출력값들로 화질 감소를 판단하기 위해서는 신호(전압, 저항, 색상 RGB 간 색조 차이 등)들을 연구자들이 직접 정의해서 추출하는데, 만약 정의한 특성이 모든 실제 상황에 대한 공통적인 특징을 잘 반영하지 못할 경우 성능에 한계가 있다는 단점이 있다.

관련 선행연구로 차량용 카메라의 실시간 영상 화질 분석 기법에 관한 연구를 참고하였다[2,3]. 해당 연구는 신뢰성 평가를 위해 차량용 카메라의 영상 화질을 정량적으로 분석하여 고장을 판단하는 연구로, 고온스텝시험으로 발생한 화질 저하, 영상 왜곡을 RGB(Red, Green,

Blue) 데이터값으로 고장상태를 판단하는 프로그램을 제작하였다.

선행연구로부터 신뢰성 평가 기준으로 영상 작동 여부 뿐만 아니라 영상 왜곡, 화질 저하일 때의 고장 판단의 연구 중요성을 인식하였으며, 차량용 카메라의 신뢰성 평가 중 모니터링 시 영상은 정상적으로 출력되나, 화질 저하가 발생하면 고장으로 판정한 점을 착안하였고, 선행연구와는 달리 머신러닝을 이용하여 고장상태를 판단하고 분류하였다.

따라서, 본 연구에서는 차량용 카메라에 대해 FMEA(Failure Mode Effect and Analysis)를 수행하여 가장 치명적인 이미지센서의 고장 유형을 조사하고, 실험을 통해 이미지 데이터를 추출한 후 머신러닝 알고리즘을 적용하여 이미지센서의 고장을 진단하였다.

2. 고장모드 분석 및 실험

2.1 고장모드 분석

제품 품질 관리 자동 비전 검사 기계에 들어가는 측정 장비인 카메라의 이미지센서를 대상으로 품질 매개변수 측면에서 발생하는 결함의 원인을 표현한 FMEA 분석 결과를 Table 1에 나타내었다[4]. FMEA는 시스템에서 발생 가능한 고장과 이러한 고장으로 인해 야기될 수 있는 위험을 구조화하여 안전성과 신뢰성 평가에 널리 사용되는 도구이다. Table 1에서 알 수 있는 바와 같이 고온, 부식, 진동, 오염으로 인한 마모 등을 고장모드로 고려할 수 있다. 이 중에서 가장 높은 RPN(Risk Priority Number)인 고온으로 인한 측정 시스템의 지연은 이미지의 품질 저하에 가장 큰 영향을 미치는 요인으로 판단된다.

한국소비자원(www.kca.go.kr)의 조사에 따르면, 시중에 유통 중인 차량용 카메라 31대를 대상으로 고온 작동 시험을 시행한 결과, Table 2에 나타난 바와 같이 60℃에서 9개(29%), 90℃에서 22개(71%) 제품에서 화질 저하 문제가 발생했다[5]. 자동차 문이 잠기면 평균 30분 만에 4.4℃가 상승하며, 섭씨 30℃인 날에 자동차 안 온도는 68℃까지 상승할 수 있기 때문에 고온으로 인한 측정 시스템의 지연을 주요 고장모드로 선정하였다[6].

자율주행 기술 개발과 함께 주변 환경을 분석하는 차량 내 센서 파트의 고장은 안전한 주행에 있어서 치명적이다. 따라서 온도 조건을 변화시켜 가면서 연속적인 상태별 사진 데이터를 통해 카메라 이미지센서의 고장진단 모델을 제작하였다.

Table 1. FMEA worksheet for Image Sensor

Potential causes of failure modes	Occurrence	Severity	Detection	RPN
Incorrect location of elements relative to the measuring system	2	8	2	32
Large vibrations of the mechanical system due to faulty construction	6	8	3	144
Delayed reaction of the measuring system to changes in ambient temperature and temperature of the element being inspected	6	8	5	240
Inappropriate use of vibration damping elements	9	7	2	126
Insufficient protection against high temperatures	8	6	3	164
Poor protection against pollution, oil emulsions, dust	8	6	3	164
Inappropriate use of protection screens	8	6	3	164

Table 2. Vehicle camera high temperature operation test results

	60℃	70℃	80℃	90℃
Number	9	13	17	22
Percentage	29%	42%	55%	71%

Table 3. Specification of camera

Model	IPASS Black N9
Image sensor	F22(1/2.7 inch CMOS)
Voltage	DC 12~24V
Temperature	-20~70℃




Fig. 1. Failure Prognostics data collection system conceptual diagram

2.2 실험 장치 및 방법

카메라의 이미지센서로부터 데이터를 추출하기 위해 Fig. 1과 같이 온도 챔버, 차량용 카메라, 이미지센서, 컴퓨터 등으로 실험 장치를 구성하였으며, 선정된 차량용 카메라의 사양은 Table 3과 같다.

차량용 카메라 내 이미지센서를 실험하기 위해 차량용 카메라 PCB(Printed Circuit Board) 기판에서 이미지 센서를 제외한 부분에는 단열재를 추가하여 불필요한 부분에 가해지는 열을 최소화하였다. 실험조건은 고온스텝 시험을 통해 차량용 카메라의 영상 화질을 분석한 선행 연구의 실험방안에 착안하여 10℃ 간격으로 70, 80, 90, 100, 110℃ 에 노출시켜 실험을 진행하였으며, 동일한 시간을 정하여 누적되는 손상결과로부터 고장진단이 가

능하도록 실험하였다. 그리고 여러 가지 온도에 노출시켜 추출된 화질이 불량한 데이터를 데이터 증폭(Data Augmentation)과 전처리를 수행한 후 이미지 분류에 특화된 CNN(Convolutional Neural Networks) 모델을 이용하여 이미지 분류 알고리즘을 제작하였다.

3. 머신러닝을 이용한 고장진단

3.1 데이터 수집 및 분류

FMEA의 고장모드 분석 결과로부터 온도를 주요 파라미터로 선정하여 데이터를 수집 및 분석하였으며, 정상 상태 이미지와 고장상태 이미지의 화질 특성을 비교하기 위해 이미지센서로부터 데이터를 확보하였다.


차량용 카메라 PCB 기판을 온도 챔버에 70, 80, 90, 100, 110℃ 로 각각 2시간씩 노출시켜 화질이 불량한 데이터를 준비하였다. 측정한 영상을 1초 단위로 잘라 넣었으며, 온도마다 데이터 세트를 얻어 총 6,123장의 데이터 세트를 준비하였다. 이후 수집된 원본 이미지를 수평 또는 수직 반전, 25° 회전, 일부 영역 제거, RGB 채널 순서를 바꾸거나 픽셀값을 변경하였으며, 원본 이미지의 색조를 변경시켜 데이터를 증강하는 방식을 통해 데이터를 전처리하였다. 데이터 세트는 용도에 따라 Training,



(a) Healthy



(b) Fault 1



(c) Fault 2

Fig. 2. Healthy and fault images

Validating, Testing으로 구분하였으며, Training에 사용한 데이터는 전체 데이터의 50%, Validating에는 전체 데이터의 25%, Testing은 전체 데이터의 25%를 사용하였다. 육안으로 정상(Healthy) 3,048장, 화질 감소(Fault 1) 2,040장, 불량(Fault 2) 1,035장을 라벨링 하여 Fig. 2와 같이 나타내었다. 라벨링 된 사진을 머신러닝에 사용하기 위해서는 범주화를 해야 하며, 이를 위해 One-Hot Encoding을 사용하였다. One-Hot Encoding은 0으로 이루어진 벡터에 단 하나만 1을 가지게끔 하여 데이터를 구분하는 방식으로, 준비된 데이터의 라벨이 총 3가지이므로 우리는 3개의 비트를 사용하여 Table 4와 같이 벡터를 구성하였다.

Table 4. One-Hot Encoding

	Vector
Healthy	[1,0,0]
Fault 1	[0,1,0]
Fault 2	[0,0,1]




Fig. 3. Performance comparison with different classifiers

3.2 고장진단 알고리즘 적용

머신러닝은 인공지능의 한 분야로 컴퓨터가 학습해서 판단하는 알고리즘을 통칭한다. 그중 최근엔 딥러닝(Deep Learning)이 많이 사용되고 있는데, 딥러닝은 인간의 뉴런(Neural)을 본떠 만든 인공신경망을 기반으로 대량의 데이터를 통해 컴퓨터가 뉴런의 가중치들을 조정하며 스스로 학습하는 머신러닝 알고리즘의 한 분야이다.

특히 딥러닝 알고리즘 중 하나인 CNN은 이미지 처리 분야에서 최근 많은 주목을 받고 있다. CNN은 인간의 눈을 통해 시각 피질로 가는 일련의 신경망을 모방하여 만들어진 알고리즘으로 Fig. 3에 나타난 바와 같이 다른 머신러닝 알고리즘인 ELM(Extreme Learning Machine), SVM(Support Vector Machine), KNN(k-Nearest Neighbors) 등과 비교하여도 좋은 성능을 보인다[7,8].

비디오는 연속된 개별 이미지라고 생각할 수 있으며, 앞서 개발한 CNN 모델을 통해 비디오 분류를 총 N 번 이미지 분류를 수행하였으며, 여기서 N은 비디오의 총 프레임 수를 의미한다. 프레임마다 이미지 분류를 해야 하므로 최소 1초당 30번(29.97FPS) 내외의 성능이 필요하다. 따라서 Fig. 4에 나타난 바와 같이 정확도가 낮아지는 것을 일부 고려하더라도 단위시간에 더 많은 연산을 처리할 수 있는 VGG16을 선택하였다[9].




Fig. 4. Accuracy to OPS comparison with different classifiers




Fig. 5. VGG16 Architecture

VGGNet(Visual Geometry Group Net)은 모든 합성곱 레이어에서 3×3 필터를 반복하며 결정 함수의 비선형성과 함께 모델의 특징 식별성을 증가시킨 것으로, 레이어 개수에 따라 VGG16, VGG19 등으로 불린다. 즉, VGG16은 3×3 필터를 사용하여 16-19 레이어에 달하는 깊은 신경망을 학습할 수 있고, 깊어진 네트워크의 깊이를 통해 이미지 분류 정확도가 높다[10].

본 논문에서 사용할 모델은 VGG16을 기반으로 신경망 구조를 일부 변경하였으며, 신경망 구조의 모습은 Fully Connected Layer 직전까지는 VGG16과 동일하나 마지막 출력 계층 유닛의 개수와 Fully Connected Layer를 추가하였다.

VGG16은 ILSVRC-2012를 사용하며, 해당 데이터 세트에는 1,000여 가지의 라벨을 포함하고 있으므로 VGG16의 출력층은 1,000개의 유닛을 가진다. 하지만 본 논문에서는 라벨이 총 3가지(Healthy, Fault 1, Fault 2)이기 때문에 1,000개의 유닛 대신 3개 유닛으로 출력층을 변환하여야 한다. 그러나 4,096개의 유닛 뒤 레이어에 바로 3개 유닛 레이어를 연결할 시 특성을 잃

Table 5. Classified data

Types	Actual Positives	Actual Negatives
Positive Predictions	True Positives (TP)	False Positives (FP)
Negative Predictions	False Negatives (FN)	True Negatives (TN)

어버릴 수 있으므로 Fully Connected 4,096 Layer(4,096)를 2개로 나누어 2,048개의 Unit Layer와 1,024개의 Unit Layer를 연결하고, 마지막 출력층으로 3개의 Unit Layer를 추가로 연결하여 Fig. 5와 같이 네트워크를 구성하였다.

학습할 때 사용한 손실 함수는 Categorical Cross Entropy를 사용하였고, 50 Epoch를 학습하였다. Categorical Cross Entropy는 라벨이 3개 이상인 경우 출력을 각 클래스에 속할 확률을 예측하는 경우에 사용한다. 본 논문에서는 3가지 라벨(Healthy, Fault 1, Fault 2)로 데이터를 분류하였으므로, Categorical Cross Entropy를 사용하기에 적절하다. Eq. (1)과 같은 공식으로 실제 값과 예측값이 다른 경우 수식에 대입하면 양의 무한대로 발산하고, 같은 경우 0으로 수렴하기 때문에 두 확률분포가 서로 얼마나 다른지를 나타내주고 학습 속도를 올려주며 이 값을 최소화하도록 모델을 학습한다.

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C t_{ij} \log(y_{ij}) \quad (1)$$

Where, N denotes the total number of data sets, C denotes the number of labels, t_{ij} denotes j -th element among the actual value One-Hot Encoded values, y_{ij} denotes j -th element of the predicted value.

4. 고장분류 결과 및 고찰

FMEA를 기반으로 온도에 따른 정상상태 데이터와 고장상태 데이터의 이미지를 비교하였다. 이미지센서로부터 획득한 데이터의 결과를 통해 온도가 증가함에 따라 데이터의 화질이 저하되고, 이미지센서가 표현하는 색상에 변화가 있는 것을 확인할 수 있었다.

머신러닝에 의한 분류 성능을 평가하기 위해서는 Table 5와 같이 4가지 지표를 사용하는데, 여기서 TP는 분류기가 Positive를 Positive로 정확하게 예측하는 수,

Table 6. Classification performance by VGG

Classes	Precision	Recall	F1-score	Accuracy
Fault 1	0.99	0.97	0.98	0.98
Fault 2	0.75	0.75	0.75	
Healthy	0.99	1.00	0.99	




Fig. 6. Training results using CNN

TN은 Negative를 Negative로 정확하게 예측하는 수, FP는 Negative를 Positive로 잘못 예측하는 수, FN은 Positive를 Negative로 잘못 예측하는 수를 의미한다. VGG16 알고리즘을 적용한 분류 성능은 Eq. (2) ~ (5)를 이용하여 Table 6과 같이 나타내었으며, Precision은 모델이 참이라고 예측한 것 중 실제로 참인 비율, Recall은 실제 참인 것 중 모델이 참이라고 예측한 비율, F1-score는 Precision과 Recall의 조화평균, Accuracy는 참을 참이라 하고 거짓을 거짓이라고 분류한 것의 비율을 의미한다[11].

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

Table 6으로부터 Accuracy는 98%이며, Fault 1과 Healthy에 대해 Precision은 99%, Recall은 97%, F1-score는 98% 이상의 분류 성능을 제시하고 있다. 그러나 Fault 2에서는 Precision은 75%, Recall은 75%, F1-score는 75%를 확인할 수 있다. 본 연구에서 모델의 학습 그래프를 Fig. 6에 나타내었다. 학습이 진행될수록




Fig. 7. Confusion matrix of VGG




Fig. 8. Visualization of fault image using Grad-CAM analysis

Loss가 감소하고 Accuracy가 증가하는 것을 확인할 수 있으며, Accuracy는 30번째부터 0.98로 수렴하고, Loss는 35번째부터 0.02로 수렴하였다. 이때 모델의 F1-Score와 Confusion Matrix를 Fig. 7에 표시하였다. Fault 2의 경우 고장 직전의 데이터이기 때문에 확보가 어려웠으며, 설정한 기준에 따른 표본의 수가 현저히 적어 수치가 낮게 나왔다. 이처럼 CNN 모델의 성능을 F1-score와 Confusion Matrix만으로 나타내기에는 한계가 존재한다. 즉, CNN은 이미지 한 장을 입력받아 여러 층으로 계산해 단일 값으로 표현하므로, 이미지 내부의 여러 정보가 추상적으로 변할 수 있고, 손실이 일어나기 때문에 모델이 판단한 이유나 기준을 쉽게 알 수 없게 된다.

따라서, 모델이 정확하게 학습되었는지 확인하기 위해 Grad-CAM(Gradient-weighted Class activation map)을 사용하여 모델을 시각화 분석하였으며, 모델이 이미지의 어떤 부분을 보고 판단을 내리는지 확인하였다[12]. 모델이 정상적으로 판단한 표본을 Fig. 8과 같이 나타내었으며, 입력으로 들어온 불량(Fault 2) 이미지를 모델이 불량(Fault 2)으로 판단한 경우이다. 학습된 모델이 사진의 좌측 위 가장자리에 크게 활성화된 것을 확인할 수 있으며, 이는 사진 가장자리의 열화가 모델의 판단에 영향을 준 것으로 판단된다.




Fig. 9. Failure diagnostics result

또한, 실제 도로주행에 있어서 차량용 카메라 영상에서 열화가 발생하여 고장을 일으키는 지 검증하기 위해 실제 도로에서 주행한 이미지를 통해 고장진단이 되는지 확인하였다. 기존 학습시킨 차량용 카메라 고장진단 모델에 적용하여 정확도가 가장 높은 실험 결과를 Fig. 9와 같이 나타내었으며, 많은 사진을 학습시킨 결과 평균적으로 Healthy와 Fault 1에 대해 99% 정확도를 보이고, Fault 2에 대해 84% 분류 성능으로 수렴하고 있어 학습시킨 고장진단 모델과 유사한 결과를 보인다.

차량용 카메라와 같이 높은 신뢰성을 요구하는 장비의 경우 실제 사용조건에서 대상의 고장이 발생하기까지 데이터를 수집하는 것은 한계가 있으므로 기준보다 가혹한 조건에서 실시하는 가속수명시험을 수행한다. 신뢰성을 보증할 수 있는 데이터를 수집하기 위해서는 발생 가능한 모든 고장을 파악하여 근본 원인을 확인하는 것이 중요하며, 적절한 수의 시편과 가속수명시험환경을 구성해야 하지만 실험에 사용된 시편의 수는 16개로 이러한 과정의 수행이 제한되었다. 실제 장비에 PHM을 적용할 때에는 충분한 시편의 수를 각 시험조건에 적절히 배분하여 가속수명시험을 적용하고, 가속성 검증을 수행할 것을 권장한다[13].

5. 결론

차량용 카메라 이미지센서의 고장 유형 및 영향을 FMEA를 통해 분석하였고, 온도 챔버에 이미지센서를 넣고 가열시켜서 데이터를 추출하였다. 추출한 이미지 데이터를 대상으로 CNN 기반의 VGG16 알고리즘을 적용하여 고장을 분류하였으며, 얻어진 결과를 요약하면 다음과 같다. 첫째로 고장 발생률이 가장 높은 고장 유형은 열에 의한 고장이며, 노출된 온도에 따라 이미지센서 데이터의 특성이 달라진다. 둘째로 추출된 데이터를 대상으로 VGG16 기법을 통한 머신러닝을 수행하여 이미지센서의 고장진단이 가능하다. 셋째로 VGG16 알고리즘을 사용하여 고장진단을 수행한 결과, Accuracy는 98%가 산출되었다. 넷째로 Fault 1과 Healthy에 대해 Precision은 99%, Recall은 97%, F1-score는 98%이며, Fault 2에서 Precision은 75%, Recall은 75%, F1-score는 75%이다. 마지막으로 본 실험은 사용된 시편의 수가 적어 가속수명시험 적용이 제한되었으며, 차후에는 충분한 시편의 수와 가속성 검증을 고려한 가속수명시험을 통해 데이터를 수집하여 정확한 수명예측을 진행할 예정이다.

References

- [1] Choi, J. H., "Introduction of Failure Prognosis and PHM", Journal of The Korean Society of Mechanical Engineers, Vol. 53, No. 7, pp. 24-34, 2013.
- [2] Lee, S. H., Kim, H. J., Kim, H. M and Wee, S. H., "Real-time Image Quality Analysis for Reliability Evaluation of Vehicle Camera", The Korean Reliability Society, Korea, pp. 359-364, May 2015.
- [3] Lee, S. H., Shin, M. K., Lee J. S., Wei, S. H., "Failure Mode Analysis and Reliability Verification of Automotive Camera", The Korean Society of Mechanical Engineers, Korea, pp. 134-134, February 2015.
- [4] K. Łasiński, "Application of FMEA to assessing the quality of measurement modules," Vibroengineering PROCEDIA, Vol. 3, pp. 33-38, Oct. 2014.
- [5] Joe, G. R. and Gong, G. Y., "Vehicle black box parking monitoring function, useless in heat wave", Korea Consumer Agency, Retrieved 23, July 2013. Available From: <https://www.kca.go.kr/home/sub.do?menukey=4002&mode=view&no=1001410690>
- [6] McLaren, Catherine, Jan Null, and James Quinn. "Heat stress from enclosed vehicles: moderate ambient temperatures cause significant temperature rise in enclosed vehicles." Pediatrics, Vol. 116, Issue. 1,

e109-e112., July 2005.

DOI: <https://doi.org/10.1542/peds.2004-2368>

- [7] Minhas, Rabia A., et al. "Shot classification of field sports videos using AlexNet Convolutional Neural Network." Applied Sciences, Vol. 9, Issue. 3, pp. 483, 2019.
DOI: <https://doi.org/10.3390/app9030483>
- [8] Myagila, Kasian, and Hassan Kilavo. "A comparative study on performance of SVM and CNN in Tanzania sign language translation using image recognition." Applied Artificial Intelligence, Vol. 36, Issue. 1, 2022.
DOI: <https://doi.org/10.1080/08839514.2021.2005297>
- [9] Canziani, Alfredo, Adam Paszke, and Eugenio Culurciello. "An analysis of deep neural network models for practical applications." arXiv preprint arXiv:1605.07678, 2016.
DOI: <https://doi.org/10.48550/arXiv.1605.07678>
- [10] Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition." arXiv preprint arXiv:1409.1556, 2014.
DOI: <https://doi.org/10.48550/arXiv.1409.1556>
- [11] Kim, M. S., Tanvir, A. S. and Hur, J. W., "Classification of Inverter Failure by Using Big Data and Machine Learning", Journal of the Korea Society of Manufacturing Process Engineers, Vol. 20, No. 3, pp. 1-7, 2021.
DOI: <https://doi.org/10.14775/ksmpe.2021.20.03.001>
- [12] Kim, Y. J. and Kim, E. G., "Real-Time Fire Detection based on CNN and Grad-CAM", Journal of the Korea Institute of Information and Communication Engineering, Vol. 22, No. 12, pp. 1596~1603, 2018.
DOI: <https://doi.org/10.6109/kiice.2018.22.12.1596>
- [13] Kang, Dae-Joong, and Hwa-Ki Lee. "A Study on the Reliability Prediction about ECM of Packaging Substrate PCB by Using Accelerated Life Test." Journal of the Korea Safety Management & Science, Vol. 15, Issue. 1, pp. 109-120, 2013.
DOI: <https://doi.org/10.12812/ksms.2013.15.1.109>

이 준 혁(Joon-Hyuk Lee)

[준회원]



- 2019년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학중)
- 2021년 7월 ~ 현재 : 금오공과대학교 국방신뢰성연구실 학생연구원

<관심분야>

시스템엔지니어링, 신뢰성공학, RAM, CBM+

권 민 경(Min-Gyeong Kwon)

[준회원]



- 2019년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학중)

<관심분야>

기계/재료

김 영 범(Young-Beom Kim)

[준회원]



- 2019년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학중)

<관심분야>

기계/재료

허 장 욱(Jang-Wook Hur)

[정회원]



- 1992년 10월 ~ 1995년 9월 : 일본 동경공대 기계물리공학과 (박사)
- 2009년 1월 ~ 2011년 12월 : 방사청 KHP사업단 체계종합/사업총괄담당 (중령)
- 2012년 3월 ~ 2012년 8월 : 탄약사 기술관리처장 (대령)
- 2012년 9월 ~ 현재 : 금오공과대학교 기계시스템공학과 교수

<관심분야>

시스템엔지니어링, 신뢰성공학, RAM, CBM+